

Klasifikasi Objek Bawah Laut Dengan Memanfaatkan Support Vektor Machines

Aris Tjahyanto¹

¹ Jurusan Sistem Informasi, Institut Teknologi Sepuluh Nopember
email: aristj@its.ac.id

Abstrak—Pada penelitian ini, digunakan Support Vector Machines (SVM) untuk mengklasifikasi hamburan SONAR yang dipantulkan oleh dua buah objek bawah laut, yaitu ranjau laut yang berbentuk silinder logam dan batu yang bentuknya bulat atau mendekati silinder. Untuk membuat model SVM yang sesuai untuk keperluan klasifikasi, dipakai kernel Radial Basis Function (RBF) yang diatur karakteristiknya dengan parameter faktor penalti C dan gamma γ . Kedua parameter tersebut ditentukan dengan menggunakan algoritma pencarian tapis (grid search). Pada percobaan dipilih dua pasang $[C \ \gamma]$. Pasangan yang pertama adalah $[1,4142 \ 0,25]$ mewakili model soft margin, sedangkan pasangan kedua adalah $[32 \ 0,0625]$ mewakili model hard margin. Dari percobaan yang dilakukan diperoleh bahwa SVM soft margin memberikan akurasi sebesar 92,2%. Sedangkan SVM hard margin menghasilkan akurasi sebesar 89,4%. Model SVM soft margin memberikan akurasi 92,4% atau lebih baik dibandingkan dengan akurasi 90,4% dari penelitian sebelumnya yang menggunakan jaringan syaraf tiruan dengan hidden unit sebanyak 12 buah

Kata kunci: *pembelajaran mesin, radial basis function, echo sounder, single-beam*


I. PENDAHULUAN

Echo sounder adalah salah satu jenis SONAR (Sound Navigation and Ranging), berupa perangkat yang digunakan oleh kapal laut dan ditaruh di bawah air. Echo sounder (pembangkit gema) dapat digunakan untuk menemukan objek seperti gerombolan ikan, kolom gelembung yang muncul dari dasar laut, ataupun mengetahui bentuk dasar laut.

Mengetahui suasana kedalaman air adalah hal penting dalam navigasi kapal laut dan kegiatan penangkapan ikan. Hal tersebut penting pada kegiatan navigasi agar kapal laut tidak terdampar di laut dangkal. Pada pelabuhan laut utama, terdapat peta akurat yang menjelaskan perairan di sekitarnya. Sedangkan untuk tempat lain yang belum memiliki peta akurat, maka diperlukan perangkat semacam echo sounder yang mampu untuk mengukur kedalaman air agar kapal tidak menabrak dasar laut.

Selain untuk membantu navigasi kapal laut, echo sounder dapat juga dimanfaatkan untuk mengetahui keberadaan gerombolan ikan. Dengan teknik dual-beam, ukuran ikan dapat diperkirakan berdasarkan kekuatan sinyal yang dipantulkan [1].

Pembangkit gema sorot tunggal atau single-beam echo sounder (SBES) awalnya digunakan untuk melakukan survey kedalaman perairan di sekitar pelabuhan dan sungai untuk kebutuhan navigasi. Meskipun sistem sorot-banyak makin meningkat penggunaannya, masih banyak pihak yang memanfaatkan sistem sorot tunggal karena kesederhanaannya. Cara kerja sistem sorot tunggal untuk mengukur kedalaman dapat dilihat pada Gambar 1.



Gambar 1. Mengukur kedalaman dengan menggunakan echo sounder

Pada sistem sorot tunggal, sebuah transducer biasanya dipasang pada bagian lambung kapal, tegak lurus dengan permukaan air. Sinyal akustik dengan frekuensi tertentu kemudian dipancarkan dari transducer menembus air di bawah kapal dan dipantulkan kembali oleh objek yang berada di bawah air. Jenis objek dapat diperkirakan dengan mengamati karakteristik sinyal gema yang dipantulkan kembali oleh objek bawah laut [2].

Selain untuk mengukur kedalaman air, SBES dapat dimanfaatkan untuk melakukan klasifikasi objek dasar laut. Amiri et al. telah melakukan penelitian klasifikasi dasar laut dengan menggunakan sinyal SBES. Dasar laut diklasifikasikan menjadi beberapa kategori antara lain lumpur, lumpur berpasir, lumpur berkerikil, pasir, pasir berlumpur, kerikil, kerikil berpasir, dan sebagainya. Proses klasifikasi dilakukan berdasarkan sejumlah fitur yang diekstrak dari sinyal gema SBES, yaitu fitur profil energi, persebaran waktu, kecondongan (skewness), kedataran (flatness), dan principal component analysis (PCA) dari sinyal gema [3].

Agar diperoleh fitur yang bermanfaat bagi proses klasifikasi, disarankan untuk memakai SBES dengan lebar bandwidth yang cukup besar. Hal ini dikarenakan sinyal SBES yang sempit hanya menghasilkan sejumlah kecil fitur yang berguna untuk proses klasifikasi. Selain itu karena sifat alami dari sinyal akustik yang digunakan dan karakteristik dari media perambatannya, faktor yang berpengaruh terhadap hasil klasifikasi antara lain adalah kekuatan sinyal, panjang pulsa, koreksi kedalaman serta sudut datang [2].

Karakteristik dari sinyal gema dipengaruhi oleh kadar garam, suhu air laut, kedalaman dan sudut datang. Selain itu karakteristik dari sinyal gema SBES juga tergantung pada frekuensi SONAR yang digunakan. Agar proses klasifikasi dapat memberikan hasil yang memuaskan, maka perlu ditentukan cara kompensasinya agar fitur-fitur yang diekstrak dapat terbebas dari faktor-faktor tersebut [4].

Pada paper ini akan dijelaskan model klasifikasi objek bawah laut. Klasifikasi dilakukan dengan menggunakan Support Vector Machines (SVM) berdasarkan sejumlah fitur yang diekstrak dari sinyal hamburan atau gema yang diterima kembali oleh SBES setelah dipantulkan oleh objek bawah laut berupa ranjau dan batu.

1.1. Pembangkit Gema (Echo Sounder)


Echo sounder atau pembangkit gema merupakan sejenis SONAR yang secara garis besar dapat dikelompokkan menjadi dua jenis, yaitu multi beam echo sounder (MBES) dan single beam echo sounder (SBES). Perbedaan antara MBES dan SBES antara lain ditentukan dari jumlah titik kedalaman yang diukur pada saat yang sama. Pada SBES, titik kedalaman yang diukur hanya satu buah, sedangkan MBES lebih dari satu yang diukur dalam waktu yang sama [5].

Echo sounder dapat dimanfaatkan untuk mengukur kedalaman air dengan cara memancarkan sinyal denyut bunyi (sound pulse) ke dalam air. Selang waktu antara pengiriman dan kedatangan sinyal denyut dicatat, kemudian digunakan untuk menentukan kedalaman air berdasarkan kecepatan rambat bunyi dalam air. Pada MBES, sinyal denyut dibangkitkan dengan sudut yang lebar berbentuk kipas di bawah lambung kapal. Pantulan sinyal gema oleh objek dasar laut diterima dari sejumlah sinyal denyut yang dipancarkan dalam sudut yang sempit. Kedalaman air kemudian diekstrapolasi sepanjang pita yang terbentuk dari petak-petak kedalaman dasar laut.

Echo sounder dapat dipasang pada perahu atau kapal untuk mengetahui gerombolan ikan dan pola penyebarannya. Selain itu, echo sounder dapat pula dipasang pada lokasi yang tetap seperti pada pintu air sungai untuk memantau ikan-ikan yang berlalu lalang. Akurasi dari echo sounder dalam mendeteksi objek bawah air ditentukan antara lain oleh daya atau kekuatan sinyal yang dipancarkan. Semakin besar daya yang dimiliki echo sounder, maka semakin tinggi peluang untuk memperoleh pantulan sinyal gema dari kedalaman air, dengan kata lain semakin besar kedalaman yang dapat dicapai. Selain itu, semakin besar daya yang dipancarkan, maka semakin mudah untuk membedakan sinyal gema yang berasal dari objek seperti ikan dengan sinyal gema yang berasal dari dasar laut.

Selain faktor daya, akurasi echo sounder juga ditentukan oleh frekuensi yang digunakan. Frekuensi tinggi cocok digunakan untuk kedalaman air hingga 60 meter. Sedangkan frekuensi rendah lebih cocok untuk air yang lebih dalam karena air menyerap lebih lambat gelombang bunyi yang memiliki frekuensi rendah sehingga sinyal gema dapat merambat lebih jauh dibanding frekuensi tinggi. Hanya saja sinyal frekuensi rendah memiliki sudut sorot yang lebih lebar yang mengakibatkan kurang tajamnya gambaran yang diberikan. Objek dasar laut seperti lumpur, pasir lembut, dan tumbuhan yang berada di dasar akan menyerap dan atau menghamburkan sinyal gema yang mengakibatkan tampilan dasar yang gelap dan tebal.


Pilihan frekuensi SONAR yang tersedia di pasaran adalah sangat banyak. Perbedaan frekuensi akan memberikan tingkat kejelasan gambar yang berbeda pula. Sebagai contoh, frekuensi 1600 kHz menghasilkan gambar yang lebih tajam atau memiliki resolusi yang lebih baik dari pada SONAR dengan frekuensi 400 kHz. Akan tetapi apabila yang dipentingkan adalah area pencarian yang lebih luas, maka frekuensi yang lebih rendah adalah pilihan yang cocok. Secara praktis, biasanya setiap transduser SONAR dilengkapi dengan frekuensi ganda, sebagai contoh sebuah SONAR dilengkapi dengan frekuensi 200 kHz dan 50 kHz. Frekuensi yang lebih tinggi digunakan untuk memperoleh hasil resolusi yang tinggi, sedangkan frekuensi rendah untuk keperluan area pencarian yang lebih luas. Berikut ini adalah sinyal ping SONAR dengan frekuensi 2 kHz.



Gambar 2. Salah satu bentuk sinyal ping SONAR dengan frekuensi 2 kHz.

1.2. Objek Bawah Air dan Pola Hamburan

Pada identifikasi objek bawah air; target objek yang dideteksi biasanya meliputi pasir, lumpur, kerikil, tanaman, ranjau, batu, dan lainnya. Target objek tersebut menyebabkan mekanisme penghamburan sinyal menjadi kompleks, karena targetnya bukanlah sebuah objek yang kaku. Pada SONAR monostatik, hal yang pertama kali didengar oleh penerima adalah suara sinyal ping yang telah dikirim. Secara teori, adalah tidak mungkin untuk mendeteksi gema pada durasi τ atau dengan kata lain sebuah target tidak dapat terdeteksi pada radius sebesar $\frac{1}{2} \tau c$, dengan c adalah kecepatan bunyi dalam air. Objek target tidaklah memantulkan sinyal ke segala arah. Mekanisme pemantulannya adalah kompleks [6]. Tingkat sinyal gema yang dipantulkan tergantung pada sudut β dan sudut pantul α (Gambar 3). Mekanisme pantulan juga menjadi lebih kompleks jika objek target terkubur atau setengah terkubur sedimen dasar laut seperti ranjau laut, sampah, kapal karam, dan sebagainya.




Gambar 3. Pola hamburan sinyal SONAR oleh target bawah air

1.3. Algoritma Klasifikasi

Klasifikasi merupakan salah satu fungsi penggalian data (data mining) dan pembelajaran mesin (machine learning) yang akan menempatkan sebuah butir data ke dalam kategori atau kelas tertentu. Tujuan dari klasifikasi adalah secara akurat memprediksi kelas tujuan untuk setiap kasus butir data yang diamati. Terdapat banyak permasalahan klasifikasi, sebagai contoh adalah kategorisasi teks (misal: penyaringan spam), deteksi penggelapan (fraud), pengenalan huruf, pengenalan suara, deteksi wajah, pengolahan bahasa alami, segmentasi pasar, bioinformatika dan lain-lain.

Sampai saat ini terdapat banyak algoritma klasifikasi yang biasa digunakan oleh peneliti. Menurut Xindong Wu et.al., terdapat sepuluh algoritma klasifikasi yang meliputi antara lain: C4.5, k-Means, SVM, Apriori, EM, PageRank, AdaBoost, kNN, Naive Bayes, dan CART. Sepuluh buah algoritma klasifikasi tersebut adalah yang paling berpengaruh dalam komunitas penelitian [7].

Pada era sekarang, support vector machines (SVM) adalah algoritma yang perlu dipertimbangkan dan dicoba. SVM menawarkan sebuah metode yang akurat dan tangguh di antara algoritma yang lain. SVM memiliki dasar teori yang masuk akal, memerlukan hanya satu lusin data untuk tahap pelatihan serta tidak sensitif terhadap ukuran atau dimensi data [7].



Gambar 4. SVM untuk data biner

Untuk kelas biner, tujuan SVM adalah mencari fungsi klasifikasi terbaik yang dapat membedakan dua kelompok data pelatihan. Pada data yang dapat dipisahkan secara linier, fungsi klasifikasi adalah berupa hyperplane $f(x)$ yang membagi data tersebut menjadi dua. Setelah fungsi tersebut diperoleh, data baru x_n dapat diklasifikasikan secara sederhana dengan menguji tanda fungsi $f(x_n)$; x_n akan berada pada kelas positif apabila $f(x_n) > 0$.

Pada Gambar 4, diperlihatkan sejumlah support vector (diberi tanda lingkaran) yang menjadi batas margin yang memisahkan dua buah kelas. Dengan demikian setelah tahap pelatihan berhasil dilaksanakan, hanya perlu menyimpan sejumlah kecil support vector yang akan digunakan untuk melakukan prediksi pada tahap pengujian.

SVM memiliki sejumlah fungsi kernel yang digunakan untuk memetakan data pelatihan ke ruang kernel. Fungsi kernel yang tersedia antara lain adalah: linear, quadratic, polynomial, dan RBF (radial basis function). Untuk fungsi kernel RBF, terdapat dua parameter yang perlu ditentukan terlebih dulu agar diperoleh SVM yang optimal, yaitu faktor penalti C dan faktor γ . Nilai faktor C digunakan untuk menentukan sifat margin dari SVM.

II. METODE PENELITIAN

Pada penelitian ini digunakan data uji yang dibuat oleh Paul Gorman dan Terry Sejnowski (Salk Institute dan University of California at San Diego). Data uji diekstraksi dari sinyal SONAR yang dihamburkan oleh ranjau yang berbentuk silinder logam dan batu berbentuk mirip atau mendekati silinder. SONAR yang ditransmisikan berupa sinyal chirp yang termodulasi frekuensi, yang semakin bertambah semakin besar frekuensinya. Data uji berisi sinyal yang diperoleh dari berbagai sudut yang berbeda, mulai dari 90 sampai 180 derajat. Data uji berjumlah 208 buah, terdiri dari 111 buah berlabel ranjau dan 97 buah berlabel batu [8].

Data uji terdiri dari 60 buah fitur yang bernilai numerik yang sudah dinormalisasi sehingga bernilai dari 0,0 sampai dengan 1,0. Setiap fitur mewakili energi pada jalur frekuensi tertentu yang diintegrasikan pada periode waktu tertentu.

Data uji dibagi secara acak menjadi 13 kelompok yang saling disjoint atau terpisah satu sama lain alias tidak saling beririsan. Setiap kelompok terdiri dari 16 buah data. Pada setiap percobaan, 12 kelompok data digunakan sebagai pelatihan atau training, sedangkan sisanya digunakan sebagai data pengujian. Percobaan diulangi 13 kali, serta dicatat kinerja rata-rata masing-masing.

Sebelum dilakukan pengujian, terlebih dulu dilakukan penentuan parameter model SVM yang optimal dengan menggunakan teknik pencarian tapis (grid search) [9] berdasar 12 kelompok data pelatihan. Dengan memanfaatkan parameter optimal tersebut, model SVM kemudian dibangun dan dilanjutkan dengan tahap pengujian.


Untuk menganalisis model classifier SVM yang telah dibuat apakah memiliki kredibilitas, digunakan kurva ROC (Receiver Operating Characteristic) yang menunjukkan hubungan antara uji sensitifitas (true positive rate) dan spesifisitas (1 - false positive rate). Kurva ROC akan memberikan nilai Area Under Curve (AUC) sebesar 0,5 sampai dengan 1,0. Nilai AUC sebesar 0,5 dapat diartikan bahwa kemungkinan kesimpulan benar dan salah adalah sama besarnya. Secara teoritis, nilai AUC yang ideal adalah sebesar 1,0 [10].

III. HASIL DAN PEMBAHASAN

Untuk membuat model SVM yang optimal, diperlukan ketepatan pemilihan nilai besaran parameter fungsi kernel. Pada fungsi kernel radial basis (RBF), parameter yang diperlukan adalah gamma (γ) dan faktor penalti (C). Ketepatan pemilihan parameter tersebut akan mempengaruhi akurasi klasifikasi dan kinerja SVM.

Salah satu cara yang biasa digunakan untuk memilih nilai parameter fungsi kernel SVM adalah dengan menggunakan algoritma pencarian tapis. Algoritma tersebut memiliki keuntungan antara lain kesederhanaan penggunaannya dalam pencarian parameter-parameter fungsi kernel. Sedangkan kekurangan dari algoritma pencarian tapis adalah besarnya perhitungan yang harus dikerjakan, dan sulitnya menentukan rentang nilai parameter yang perlu diperiksa.

Pada percobaan pertama pencarian tapis, diperoleh nilai $C = 32$ dan $\gamma = 0,0625$ memberikan kinerja terbaik seperti yang terlihat pada Gambar 5. Faktor penalti C menentukan besar kecilnya ongkos yang harus dibayar terhadap kesalahan klasifikasi. Semakin besar nilai C, semakin tinggi ongkos kesalahan klasifikasi yang harus dibayar karena semakin sempit margin yang digunakan untuk memisahkan antar kelompok atau kelas. Semakin besar nilai C, semakin mudah sistem mengalami overfitting. Parameter γ dapat berkisar mulai dari 0 sampai dengan ∞ . Parameter ini berguna untuk menangani klasifikasi non-linier, dengan cara mengontrol bentuk “puncak” dari permukaan “bell-shaped” yang terbentuk dari support vector yang diperoleh pada tahap pelatihan. Semakin kecil nilai γ , maka semakin runcing bentuk permukaannya, dan sebaliknya.




Gambar 5. Hasil grid-search untuk penentuan parameter terbaik

Pada percobaan kedua pencarian tapis, diperoleh nilai optimal untuk $C = 1,4142$ dan $\gamma = 0,25$. Percobaan kedua dilakukan dengan mengganti nilai kenaikan $\log_2(C)$ dari 1 menjadi 0,25 sehingga memungkinkan proses pencarian yang lebih detail. Dengan memanfaatkan nilai faktor penalti C yang lebih kecil memberikan kinerja SVM yang lebih baik seperti yang terlihat pada tabel 1. Secara rata-rata, percobaan pertama memberikan akurasi sebesar 89,4%. Sedangkan pada percobaan kedua akurasinya naik menjadi 92,2% setelah menerapkan faktor penalti C yang lebih kecil.

Tabel 1. Akurasi SVM untuk deteksi ranjau dan batu.

No	Akurasi Klasifikasi (%)	
	$C=32$ $\gamma=0,0625$	$C=1,4142$ $\gamma=0,25$
1	93,8	100,0
2	93,8	96,9
3	93,6	95,7
4	90,5	92,1
5	92,3	93,6
6	88,4	89,5
7	87,3	89,1
8	85,7	88,9
9	85,3	88,1
10	82,9	88,0
11	81,7	86,9
12	80,7	86,5
13	81,3	87,5
Rerata	89,4	92,2

Sebuah kurva ROC dapat digunakan untuk menunjukkan imbal balik antara sensitivitas dan spesifisitas. Atau dengan kata lain, adanya kenaikan sensitifitas akan disertai dengan penurunan spesifisitas. Jika kurva ROC semakin mendekati pojok kiri atas, maka semakin akurat pengujian yang dilakukan. Dengan demikian sebuah pengujian akan sangat akurat jika sensitifitasnya sebesar 1 dan spesifisitasnya 1 (atau memiliki false positive rate bernilai 0).



Gambar 6. Kurva ROC

Akurasi atau ketepatan dari sebuah classifier dapat diukur dengan menggunakan luas daerah di bawah kurva ROC (area under the curve atau AUC). Dari percobaan, diperoleh nilai AUC sebesar 0,93527 seperti

yang terlihat pada Gambar 6. Oleh karena nilai $AUC \geq 0,9$ maka dapat diartikan bahwa classifier SVM yang digunakan adalah sangat baik dan mampu [10] membedakan antara objek ranjau dan batu.

Tingkat akurasi penelitian ini secara rata-rata lebih baik dari akurasi yang dilakukan oleh Gorman dan Sejnowski. Gorman dan Sejnowski melakukan klasifikasi ranjau dan batu dengan memanfaatkan jaringan syaraf tiruan dengan jumlah hidden unit yang bervariasi mulai dari 0 sampai dengan 24 buah seperti yang terlihat pada Tabel 2.

Berdasar Tabel 2 tersebut, diketahui bahwa maksimal akurasi yang didapatkan oleh Gorman dan Sejnowski adalah sebesar 90,4. Akurasi tersebut diperoleh pada jaringan syaraf tiruan dengan hidden unit berjumlah 12 untuk data uji angle-dependent.

Tabel 2. Akurasi Jaringan Syaraf Tiruan untuk deteksi ranjau dan batu [8].

#Hidden Unit	Akurasi (%)	
	Angle independent	Angle dependent
0	77,1	73,1
2	81,9	85,7
3	82,0	87,6
6	83,5	89,3
12	84,7	90,4
24	84,5	89,2

Rata-rata akurasi yang diperoleh dengan menggunakan SVM adalah sebesar 92,2 kemungkinan masih dapat ditingkatkan lagi. Kuncinya adalah penentuan parameter gamma γ dan faktor penalti C. Sebisa mungkin dipilih nilai faktor penalti sekecil-kecilnya untuk menghindari fenomena overfitting. Tanda-tanda terjadinya overfitting adalah diperolehnya akurasi yang besar pada saat tahap pelatihan (training), dan justru diperoleh akurasi yang kecil pada tahap pengujian (testing). Fenomena ini terjadi karena nilai faktor penalti yang besar menyebabkan SVM berusaha membuat margin pemisah seramping mungkin. Dengan semakin rampingnya margin SVM, maka tingkat kesalahan klasifikasi juga semakin besar yang diperoleh pada tahap pengujian.

IV. SIMPULAN DAN SARAN

Pada penelitian ini telah ditunjukkan pemakaian SVM untuk membedakan ranjau bentuk silinder dan batu berbentuk bulat. SVM yang digunakan adalah RBF dengan paramater $C = 32$ dan $\gamma = 0,0625$. serta $C = 1,4142$ dan $\gamma = 0,25$. SVM menghasilkan rata-rata akurasi sebesar 89,4% dan 92,2%. Hasil SVM ini lebih bagus dari pemakaian jaringan syaraf tiruan yang hanya menghasilkan akurasi maksimal sebesar 90,4% pada penelitian sebelumnya.

Penelitian ini juga membuktikan bahwa ketepatan penentuan nilai paramater C dan γ akan memberikan hasil akurasi yang signifikan. Sekaligus mendemonstrasikan bahwa SVM dapat mengungguli jaringan syaraf tiruan untuk proses klasifikasi atau identifikasi objek.

DAFTAR PUSTAKA

- [1] K. Iida, T. Mukai, and K. Ishii, "Application of a dual beam echo sounder to measuring fish length," Nippon Suisan Gakkaishi, vol. 57, no. 4, pp. 623–627, 1991.
- [2] T. T. Lied, M. Walday, F. Olsgard, K. E. Ellingsen, and S. Holm, "SEABEC - A single beam echo sounder seabed classification system," in OCEANS '04. MTS/IEEE TECHNO-OCEAN '04, 2004, vol. 4, pp. 2024–2028.
- [3] A. R. Amiri-Simkooei, M. Snellen, and D. G. Simons, "Principal Component Analysis of Single-Beam Echo-Sounder Signal Features for Seafloor Classification," Ocean. Eng. IEEE J., vol. 36, no. 2, pp. 259–272, Apr. 2011.
- [4] P. Hung, S. McLoone, and X. Monteys, "Seabed type clustering using single-beam echo sounder time series data," in 6th WSEAS International Conference on Remote Sensing, Iwate, Japan, 2010, pp. 308–315.
- [5] A. I. EL-Hattab, "Single beam bathymetric data modelling techniques for accurate maintenance dredging," Egypt. J. Remote Sens. Space Sci., vol. 17, no. 2, pp. 189–195, 2014.

-
- [6] H. Cox, “Fundamentals of Bistatic Active Sonar,” in *Underwater Acoustic Data Processing*, Dordrecht: Kluwer Academic Publishers, 1989, pp. 3–24.
 - [7] X. Wu, V. Kumar, J. Ross Quinlan, J. Ghosh, Q. Yang, H. Motoda, G. J. McLachlan, A. Ng, B. Liu, P. S. Yu, Z.-H. Zhou, M. Steinbach, D. J. Hand, and D. Steinberg, “Top 10 Algorithms in Data Mining,” *Knowl Inf Syst.*, vol. 14, no. 1, pp. 1–37, Dec. 2007.
 - [8] R. P. Gorman and T. J. Sejnowski, “Analysis of hidden units in a layered network trained to classify sonar targets,” *Neural Netw.*, vol. 1, no. 1, pp. 75–89, 1988.
 - [9] C. Hsu, C. Chang, and C. Lin, *A practical guide to support vector classification*. 2010.
 - [10] T. Fawcett, “An Introduction to ROC Analysis,” *Pattern Recogn Lett*, vol. 27, no. 8, pp. 861–874, Jun. 2006.